



中国科技期刊卓越行动计划项目入选期刊

控制与决策

C O N T R O L A N D D E C I S I O N



基于感知融合的自适应无创呼吸机技术研究

邓子亨, 李敏希, 沈大伟, 邹建伟, 邓庆绪

引用本文:

邓子亨, 李敏希, 沈大伟, 邹建伟, 邓庆绪. 基于感知融合的自适应无创呼吸机技术研究[J]. *控制与决策*, 2024, 39(7): 2421–2430.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1242>

您可能感兴趣的其他文章

Articles you may be interested in

基于改进烟花算法的并联冷机负荷分配优化

Load distribution optimization of parallel chillers based on improved firework algorithm

控制与决策. 2021, 36(11): 2618–2626 <https://doi.org/10.13195/j.kzyjc.2020.0823>

基于迁移学习灰支持向量回归机的交互式进化计算

Interactive evolutionary computation based on transfer learning grey support vector regression

控制与决策. 2021, 36(10): 2399–2408 <https://doi.org/10.13195/j.kzyjc.2020.0420>

基于深度强化学习与迭代贪婪的流水车间调度优化

Scheduling optimization for flow-shop based on deep reinforcement learning and iterative greedy method

控制与决策. 2021, 36(11): 2609–2617 <https://doi.org/10.13195/j.kzyjc.2020.0608>

基于反向学习的群居蜘蛛优化WSN节点定位算法

WSN node localization based on social spider optimization and opposition based learning

控制与决策. 2021, 36(10): 2459–2466 <https://doi.org/10.13195/j.kzyjc.2020.0258>

融合长短时记忆机制的机械臂多场景快速运动规划

Multi-scene rapid motion planning combining with long and short time memory mechanisms for manipulators

控制与决策. 2020, 35(12): 2968–2976 <https://doi.org/10.13195/j.kzyjc.2018.1387>

基于感知融合的自适应无创呼吸机技术研究

邓子亨¹, 李敏希¹, 沈大伟¹, 邹建伟², 邓庆绪^{1†}

(1. 东北大学 计算机科学与工程学院, 沈阳 110167; 2. 中铁九局集团电务工程有限公司, 沈阳 110013)

摘要: 随着全球老龄化和呼吸系统疾病增加, 无创呼吸机使用场景逐渐从医院转向日常家庭, 因此迫切需要呼吸机具备更强的自主适应能力, 以针对不同病症进行个性化治疗。然而, 目前呼吸机产品智能化程度较低, 并主要受制于呼吸机对患者呼吸状态的识别能力与针对性调节呼吸机参数的自适应能力。针对以上现状, 结合感知融合、深度学习等相关技术, 设计并实现一套基于感知融合的无创呼吸机自适应算法。算法包括两个部分: 基于深度学习的参数初始化算法和基于深度学习的逐步滴定算法。参数初始化算法根据患者历史呼吸数据, 对呼吸机通气模式和参数进行初始化; 逐步滴定算法在参数初始化的基础上, 通过多种传感器实时检测患者状态参数变化, 并根据状态参数对呼吸机进行调节, 直至整个治疗环节结束。最后在仿真平台上对所提出的自适应算法进行不同呼吸症状、漏气情况的仿真实验, 结果表明所提出算法在分类准确率与回归精度等多个指标上均优于现有同类型工作, 有望加快呼吸机智能化进程, 为患者提供个性化治疗的可能性。

关键词: 无创呼吸机技术; 感知融合技术; 呼吸状态检测; 深度学习

中图分类号: TP181 文献标志码: A

DOI: 10.13195/j.kzyjc.2023.1242

引用格式: 邓子亨, 李敏希, 沈大伟, 等. 基于感知融合的自适应无创呼吸机技术研究[J]. 控制与决策, 2024, 39(7): 2421-2430.

Research of adaptive non-invasive ventilator technology based on perception fusion

DENG Zi-heng¹, LI Min-xi¹, SHEN Da-wei¹, ZOU Jian-wei², DENG Qing-xu^{1†}

(1. School of Computer Science and Engineering, Northeastern University, Shenyang 110167, China; 2. China Railway No.9 Group Co., Ltd, Shenyang 110013, China)

Abstract: With the global aging population and an increase in respiratory system diseases, the usage scenarios of non-invasive ventilators are gradually shifting from hospitals to everyday homes. Therefore, there is an urgent need for ventilators to possess stronger autonomous adaptive capabilities to provide personalized treatment for different conditions. However, the current level of intelligence in ventilator products is relatively low, mainly constrained by the ventilator's ability to recognize patient respiratory states and its adaptive capacity to adjust ventilator parameters accordingly. In response to this situation, this paper combines technologies such as sensor fusion and deep learning to design and implement a sensor fusion-based adaptive algorithm for non-invasive ventilators. This algorithm consists of two parts: a deep learning-based parameter initialization algorithm and a deep learning-based stepwise titration algorithm. The parameter initialization algorithm initializes the ventilation mode and parameters of the ventilator based on the patient's historical respiratory data. Building upon the parameter initialization, the stepwise titration algorithm monitors real-time changes in patient state parameters through various sensors and adjusts the ventilator based on these state parameters until the entire treatment process is completed. Finally, we conduct simulation experiments on the proposed adaptive algorithm on a simulation platform, simulating different respiratory symptoms and leakage scenarios. The experimental results demonstrate that the adaptive algorithm outperforms existing works of the same type in terms of classification accuracy, precision, recall, and F_1 score, which suggests the potential to accelerate the intelligence of ventilators and provide the possibility of personalized treatment for patients.

Keywords: non-invasive ventilator technology; perceptual fusion technology; respiratory state detection; deep learning

收稿日期: 2023-08-31; 录用日期: 2024-03-15.

基金项目: 国家自然科学基金项目(62072085).

责任编辑: 张国山.

†通讯作者. E-mail: dengqx@mail.neu.edu.cn.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

0 引言

随着全球呼吸系统疾病的增加,无创呼吸机一度成为全球最紧缺的医疗设备之一^[1].无创呼吸机不仅可以用于预防和治疗由COVID-19引起的呼吸系统疾病,而且对于治疗阻塞性睡眠呼吸暂停低通气综合征(obstructive sleep apnea hypopnea syndrome, OSAHS)和慢性阻塞性肺疾病(chronic obstructive pulmonary disease, COPD)等呼吸系统疾病起到重要作用^[2-3].相较于有创呼吸机,无创呼吸机不用对患者进行气管切开等额外手术,患者创伤较小,使用更加便携,因此被广泛应用于家用及医院治疗中^[4].

呼吸机经过50余年的研究发展^[5],其智能化不断提高.为了对不同自主呼吸能力和病症表现的患者进行治疗,呼吸机研究人员设计了不同的通气模式^[6-7],现市面流行的模式包括CPAP(持续气道正压通气)^[8-9]和Bi-PAP(双水平气道正压通气)^[10-12].尽管当下呼吸机都装配了多种通气治疗模式^[13],但相关配套的呼吸状态检测算法与呼吸机参数自适应设置算法并不完善.

现有呼吸机的呼吸状态检测算法主要用于检测OSAHS患者出现的hypopnea(低通气)事件与睡眠呼吸暂停事件.通过将该患者当前采集到的呼吸流量变化幅度与预先标定的正常呼吸阈值进行对比,判断是否出现突发性hypopnea与睡眠呼吸暂停事件^[14].基于阈值的呼吸检测算法存在以下两点不足:1)不同患者、不同病情程度的呼吸差异较大,预先设定的正常呼吸阈值难以进行有效检测;2)对于一些呼吸状态持续的病症,例如慢性阻塞性肺疾病(COPD)等,患者不存在正常呼吸的状态,因此无法设定对应正常阈值进行比较.

在呼吸状态检测领域,传统机器学习被广泛应用于对不同呼吸状态的识别,一些学者应用随机森林、自适应增强、SVM以及KNN等机器学习方法对呼吸状态进行分类^[15-19],但在面对复杂的临床呼吸时,研究人员手动选取的机器学习特征无法保证呼吸识别的精度.近年来,深度学习技术也开始在呼吸状态检测领域得到应用.文献[20]将单一气流提取到的17个特征输入深度神经网络(DNN)中进行状态分类,在验证集上得到85.39%的正确率.文献[21]使用6层一维卷积网络在30s的鼻流信号样本上进行分类,得到75%的正确率.文献[22]使用Bi-LSTM对多种呼吸暂停进行分类,在测试集上得到90.3%的正确率.然而,这些算法大多存在识别效率较低和缺乏可解释性的问题.目前,针对呼吸机特定领域对患者

呼吸状态识别的研究尚不成熟.

此外,在无创呼吸机运行中,由于人为或非人为导致的漏气流量逸出是呼吸机端流量传感器数据与患者端实际流量数据的主要偏差^[23],若不能准确检测出漏气量大小,则会影响对患者呼吸状态的检测.现有漏气检测算法基于过往多次呼吸的呼吸末流量值计算漏气量,存在以下两点不足:1)需要等待整个呼吸结束才对漏气量进行计算,无法及时检测呼吸中突然发生的漏气现象,对漏气响应不及时;2)只能检测漏气总量,无法对人为、非人为漏气进行细分检测,对漏气现象细节并不明确.

针对以上现有无创呼吸机存在的两个问题,提出一套无创呼吸机自适应算法,主要贡献如下:

1)首次将基于注意力机制的深度学习方法应用于呼吸机参数自适应领域,通过引入深度学习弥补现有呼吸机内呼吸状态的识别算法与参数自适应算法的欠缺.

2)首次将注意力机制引入对呼吸机漏气量的实时检测中,较现存漏气检测算法能更精确地对当前呼吸机的非人为漏气量与实际患者流量数据进行计算,并在漏气异常时产生异常警报.

3)针对突发性、常态化两类病症设计不同实时滴定算法,通过检测患者在治疗过程中产生的实时状态参数变化,自适应地对呼吸机参数进行实时调节,为患者提供个性化治疗.

仿真实验结果表明,本文提出的参数初始化算法、漏气检测算法在结果分类、回归精准度等性能指标上均高于过往同类算法.

1 问题描述

随着呼吸机使用场景逐渐日常化,目前市面上呼吸机的自适应能力显然不能满足绝大多数普通使用者的日常需求,而不适宜的呼吸机参数会延误患者的治疗周期,甚至对本身呼吸系统存在损伤的患者造成二次创伤.目前无创呼吸机领域研究对当前使用者呼吸状况的判断、实时状态检测、呼吸机参数调节等相关自适应算法的研究较欠缺,无法针对不同病症患者进行自适应参数设置与实时调节,因此提升无创呼吸机的自适应能力具有重要意义.鉴于此,本文需要解决的问题如下:1)如何通过呼吸机上传感器收集到的历史呼吸数据对患者当前状况进行识别并设置对应通气模式及初始参数;2)当呼吸机产生意外非人为漏气时,如何准确并及时地对漏气进行检测,并在异常时产生警报;3)如何通过呼吸机上传感器检测出当前患者呼吸状况,并逐步调节呼吸机参数以

满足当前使用者病症需求。

2 基于感知融合的无创呼吸机自适应算法

本文结合感知融合技术与呼吸机应用场景,以3种常用无创呼吸机治疗的呼吸病症(ARDS、COPD、OSAHS)及正常呼吸状态为例,提出一套无创呼吸机自适应算法。其中OSAHS需要由突发的睡眠呼吸暂停和hypopnea事件构成,当呼气流量相对于正常呼吸降低90%或更多且持续时间超过10s时,认为出现呼吸暂停事件。当呼气流量相对于基线降低30%或更多且持续时间超过10s时,认为出现hypopnea事件。医学上通过睡眠期间每小时出现呼吸暂停和hypopnea的总次数,即AHI指数,对OSAHS进行检测。对于本文任务,仅需获取AHI指数,因此将呼吸暂停与hypopnea统一视为hypopnea。所提出自适应算法包括参数初始化算法和逐步滴定算法两部分,整体结构如图1所示。

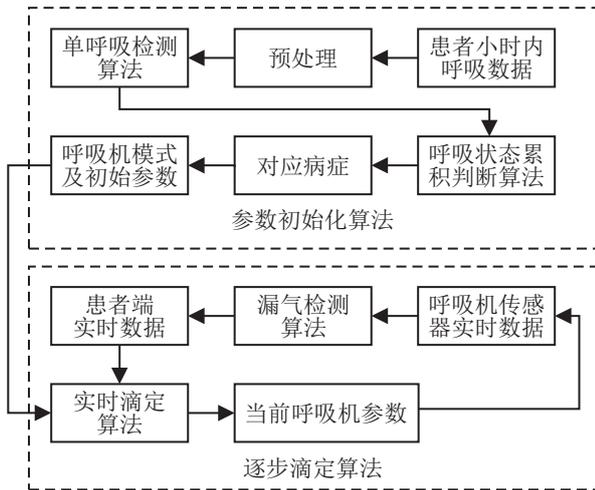


图1 呼吸机自适应整体算法结构

在参数初始化算法中,首先,通过呼吸机内的压力和流量传感器,收集患者在自发呼吸状态下1小时内的压力和流量变化曲线,并对原始时序数据进行数据小波去噪等预处理,以获得单个呼吸的数据样本;然后,将单次呼吸时序数据输入到基于注意力机制设计的单呼吸检测算法中,获得该次呼吸的状态判断结果。为了避免患者同时具备多种病症或突发性病症的情况(如突发性OSAHS),对这1小时内的单呼吸判断结果进行累积统计判断,并根据临床医学标准确定患者的状态和对应的呼吸机模式及初始参数。

在逐步滴定算法中,首先,通过呼吸机端流量传感器将患者过往15s内的流量数据与当前呼吸机输出压力输入漏气补偿算法中,得到当前时间点下呼吸机人为、非人为漏气量以及患者端流量数据;然后,将患者端流量数据与外接的血氧传感器检测到的血

氧饱和度数据输入实时滴定算法中,对不同种类病症(常态性病症、突发性病症)进行相应状态参数计算,并反馈调节呼吸机参数,直到当前患者状态参数满足对应临床医学正常氧合指标。在治疗过程中保持实时滴定算法运行,保证当患者状态发生改变时能够及时调节呼吸机参数。

2.1 基于深度学习的参数初始化算法

参数初始化算法主要包括预处理流程、单呼吸检测算法、累积判断算法3部分。呼吸机端传感器将1小时内患者呼吸数据送入预处理流程中,经过小波去噪等步骤输出分割好的单呼吸时序数据与每个呼吸对应的医学统计特征。将分割出的单呼吸时序数据与医学统计特征输入单呼吸检测算法中。该检测算法基于ResNet网络^[24]、GRU神经网络及CBAM注意力机制^[25]等深度学习结构设计。通过迭代训练优化,对预处理后的单呼吸时序数据进行单呼吸分类。最终将累积1小时的呼吸数据输入累积判断算法进行统计和阈值判断,通过对多次呼吸结果进行累积,可以规避深度学习算法出现的个别错误判断,保证输入同一病患数据得到相同输出。最终算法输出患者此时呼吸状态和对应的呼吸机设定模式以及初始参数,完成初始设置。

2.1.1 预处理流程

由于周围环境对仪器的影响,呼吸机内传感器采集到的原始数据主要包含两种噪声:1)采集环境、呼吸运动本身造成的高频噪声,这类噪声表现为原始信号上的毛刺现象;2)传感器本身使用时产生的基线漂移,这类噪声表现为原始波形在基线产生浮动。

本文采用小波去噪技术处理呼吸信号中的高频噪声和基线漂移。高频噪声使用sym7小波基进行5层小波分解后阈值去噪,基线漂移使用dmey小波基进行6层小波分解后阈值去噪。为适配后续单呼吸检测算法,不同呼吸状态下的连续呼吸数据被分割为单呼吸周期数据,并进行线性插值,重新采样成256维均匀大小。最终进行归一化操作以减少不同特征间的影响,得到4种呼吸状态(Normal、ARDS、COPD、Hypopnea(OSAHS))下的潮气量、流量和压力的呼吸波形如图2所示。

在后续检测算法中,除了提取不同呼吸状态的时序特征,还会考虑常用的呼吸医学统计特征。本文选取8个呼吸医学统计特征(呼吸速率、最大潮气量、呼气末的压力、平均流量、最小气道压力、最小流量、最大气道压力、最大流量)作为统计特征分支一同输入后续的单呼吸检测算法中。

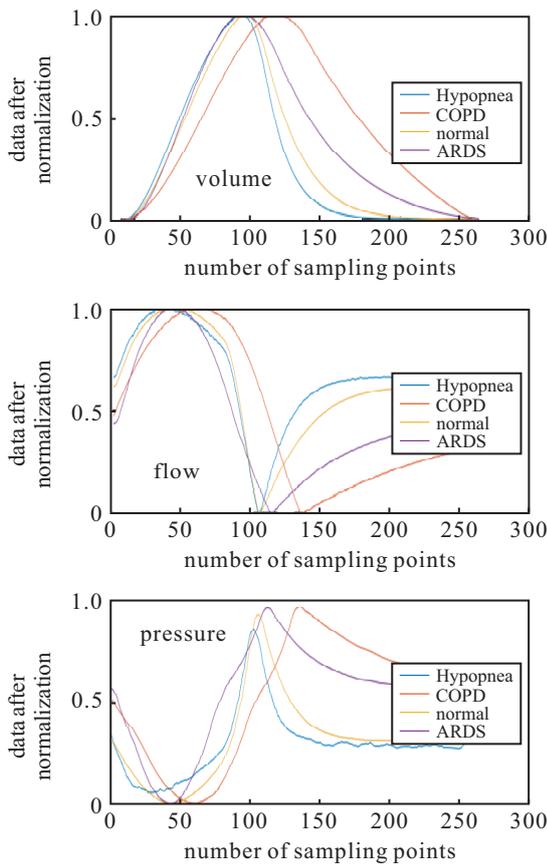


图2 经过预处理后的潮气量、流量、压力数据曲线

2.1.2 基于注意力机制的单呼吸检测算法

为了能对患者历史呼吸数据中每次呼吸状况进行检测,本文设计了基于注意力机制的单呼吸检测算法,如图3所示.该网络基于呼吸机输出的压力、流量、潮气量序列与预处理阶段提取的医学统计特征对当前呼吸的类型进行分类.算法由两个并行网络分支组成,其中序列性特征分支输入单次呼吸的压力、流量、潮气量与对应时间步数据用于提取呼吸时序数据的特征;统计学特征分支输入信号预处理阶段中基于临床医学提取出的8个医学统计呼吸特征.最终算法结合两个特征分支提取出的特征完成对单次呼吸类别的分类.

序列性特征分支主要由提取多尺度信息特征的Residual Block与捕获信号中深层长期依赖信息的Recurrent Block组成. Residual Block由两个特殊卷积块与一个残差运算组成,如图3所示.其中第1个卷积块中的CBAM注意力模块^[26]由通道注意力机制和空间注意力机制构成,通过通道、空间注意力机制对特征图中各通道、空间位置进行加权.针对性地关注对分类有帮助的特征,抑制无关的特征,达到动态化调整输出特征图的目的. Recurrent Block使用Bi-GRU双向门控网络作为其循环网络部分,引入注意力机制^[27]解决序列较长时出现的特征冗余问题.通

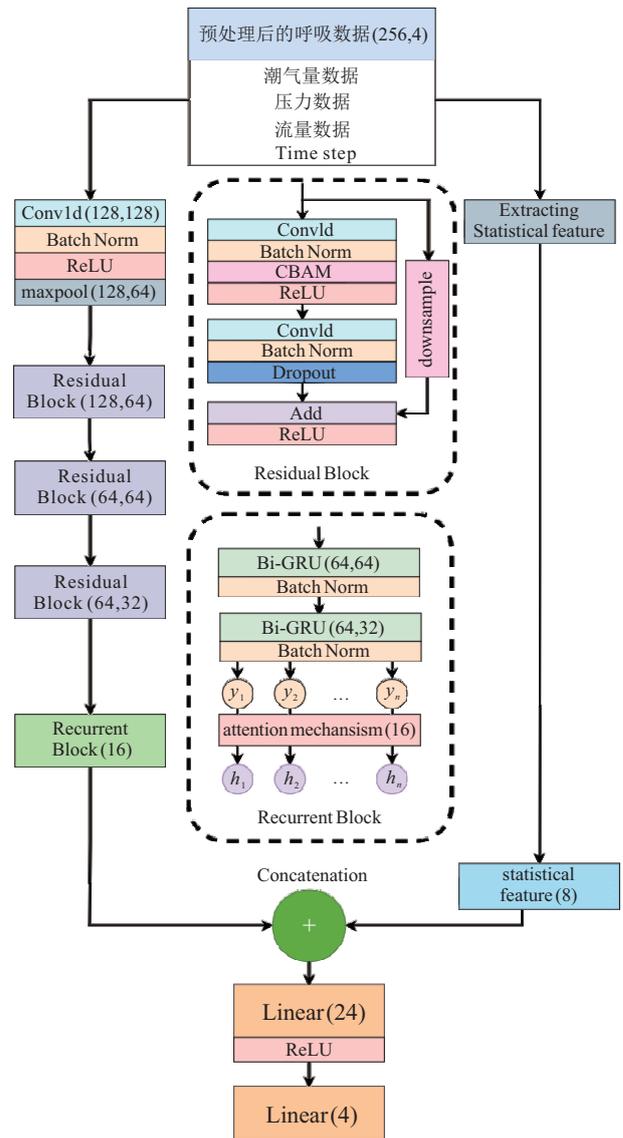


图3 基于注意力机制的ResNet-GRU单呼吸检测算法

过在循环类网络后引入注意力机制可以在不增加模型计算代价的情况下提高网络可解释性,实现时间序列中重要细粒度特征的提取.

统计特征分支将预处理阶段中统计出的8个医学统计特征作为一维特征向量输入单呼吸检测模型,以弥补序列性特征分支提取特征时的部分遗漏.

最后,将序列性特征分支与统计特征分支的特征进行拼接,经过两层全连接层输出分类标签.

2.1.3 累积判断算法及初始参数设置

得到1小时内呼吸的分类结果后,将其输入累积判断算法判断对应病患的状态,算法通过统计多次呼吸结果避免了单呼吸检测算法中可能产生的分类错误,且符合临床医学对相关病症的判断标准.

根据实际识别需求,累积判断算法将呼吸状态分为常态性病症与突发性病症两类,其中常态性病症的呼吸状态会在发病期间保持,并在短时间内不会出现过大变化,累积判断算法关注于对应呼吸类别所占比

例. 突发性病症则由多个突发异常事件组成, 累积判断算法关注于对应异常事件发生的次数.

首先对常态性病症如 COPD、ARDS 状态进行判断. 算法统计对应呼吸类型所占整体呼吸集的比例后进行阈值比较, 若该呼吸类别所占比例大于该类别设定的阈值, 则认为当前患者处于对应呼吸状态. 因此, 呼吸类别的阈值设置决定了呼吸状态判断算法的精准度, 阈值大小的具体设置实验在 3.1.2 节进行介绍.

对突发性病症 OSAHS 状态进行判断. 如前文所述, 关注其在 1 小时内 AHI 指数的大小, 即每小时内低通气与呼吸暂停事件发生的次数. 因此为了判断当前患者是否处于 OSAHS 状态, 需要将单次呼吸检测算法识别出的 Hypopnea (OSAHS) 呼吸类型转化为 AHI 指数, 具体如算法 1 所示. 在得到对应的 AHI 指数后, 参考 UPTODATA 临床医学数据库对 OSAHS 病症的定义, 当 AHI 指数大于 15, 即 1 小时内出现大于 15 次时视为患者处于 OSAHS 状态.

算法 1 累积判断算法.

```

input:  $D, K_A, K_C$ ; //  $D$  为 1 小时内呼吸分类结果集
output: AHI. // 当前患者 AHI 指数
1: AHI = 0;
2:  $t_{Apnea} = 0$ ; // 单次低通气事件持续时间
3: for  $i = 1, 2, \dots, N$  do
4:   if  $D_i = Apnea$  then // 当此次呼吸分类为 Apnea 时, 计算相应的 AHI 指数
5:      $t_{Apnea} = t_{Apnea} + t_i$ ; // 此次呼吸持续时间累加到单次低通气事件持续时间中, 单位为 s
6:   else
7:      $t_{Apnea} >= 10$  then
8:       AHI = AHI + 1;
9:     end if
10:     $t_{Apnea} = 0$ ;
11:  end if
12: end for
13: return AHI.
    
```

经过上述呼吸状态判断算法后得到当前患者的状态判断结果. 通过与新松医疗呼吸机工程师交流, 设定 3 种病症设置对应的通气模式与初始参数, 具体参数设置如表 1 所示. 在该参数设置下能够确保对应

表 1 各呼吸状态初始参数设置

patient status	mode settings	IPAP (cmH ₂ O)	EPAP (cmH ₂ O)	CPAP (cmH ₂ O)
ARDS	双水平正压通气	8	4	—
COPD	双水平正压通气	10	5	—
OSAHS	持续正压通气	—	—	5
Normal	—	—	—	—

病症患者在初次接受呼吸机治疗时体感较为舒适, 并对患者的呼吸运动起到一定程度的支持作用. 后续滴定算法将在此初始参数的基础上, 针对同种病症不同严重程度的患者进行特定的呼吸机参数调节.

2.2 基于深度学习的逐步滴定算法

初始参数的设置能够确保对应病症患者在初次接受呼吸机治疗时对患者的呼吸运动起到一定程度的支持作用. 但为了安全起见, 该设置通常为该病症治疗的最低压力标准. 由于患者自身状况与病情发展存在差异, 初始参数并不能满足患者的实际需要. 逐步滴定算法将在初始参数的基础上, 通过实时检测患者状态逐步将压力升高, 以保证患者在正常氧合的同时压力不会过高, 避免对患者产生伤害.

该算法主要包括漏气检测算法和实时滴定算法两个部分. 在参数初始化算法的基础上, 首先将呼吸机端传感器数据输入漏气检测算法, 得到当前呼吸机人为、非人为漏气, 进而得到患者端流量数据; 然后结合血氧传感器数据输入到实时滴定算法中. 实时滴定算法根据参数初始化算法判断出的患者病症分为突发性与常态性两类, 并针对两类病症设计对应的状态参数. 其通过实时检测对应状态参数, 在初始参数设置的基础上逐步调节呼吸机参数, 直到当前患者状态满足临床医学正常氧合指标. 在治疗过程中, 实时滴定算法会持续运行以保证当患者状况出现变化时呼吸机参数能够及时调节.

2.2.1 基于深度学习的漏气检测算法

呼吸机的自适应研究需要得到患者端的呼吸数据作为检测量. 在呼吸机实际使用过程中难以直接采集到患者端流量变化, 只能通过呼吸机端流量传感器采集到的数据拟合出患者端的呼吸数据. 但由于漏气造成流量逸出, 呼吸机端传感器数据与患者端的呼吸数据存在偏差, 若要使自适应算法的结果正确, 准确检测出漏气量的大小至关重要.

当呼吸机输出压力固定时, 整个呼吸过程中随着漏气程度变化, 呼吸机端检测到的流量与人为、非人为漏气呈现某种非线性关系. 此外, 在单个呼吸运动中, 呼吸机端检测到的流量与人为、非人为漏气流量之间呈现某些周期性规律. 基于以上分析本文设计了漏气检测算法, 通过学习呼吸机输出压力、呼吸机端流量与对应人为、非人为漏气之间的关系, 达到输入呼吸机输出压力和呼吸机端流量, 输出对应人为、非人为漏气的回归值.

模型由两个并行网络分支组成, 算法结构如图 4 所示. 其中左侧为时序特征分支, 输入过去 15 s 内呼

吸机端流量传感器检测到的时序数据. 右侧为协变量分支, 输入该时间下呼吸机设定压力参数值.

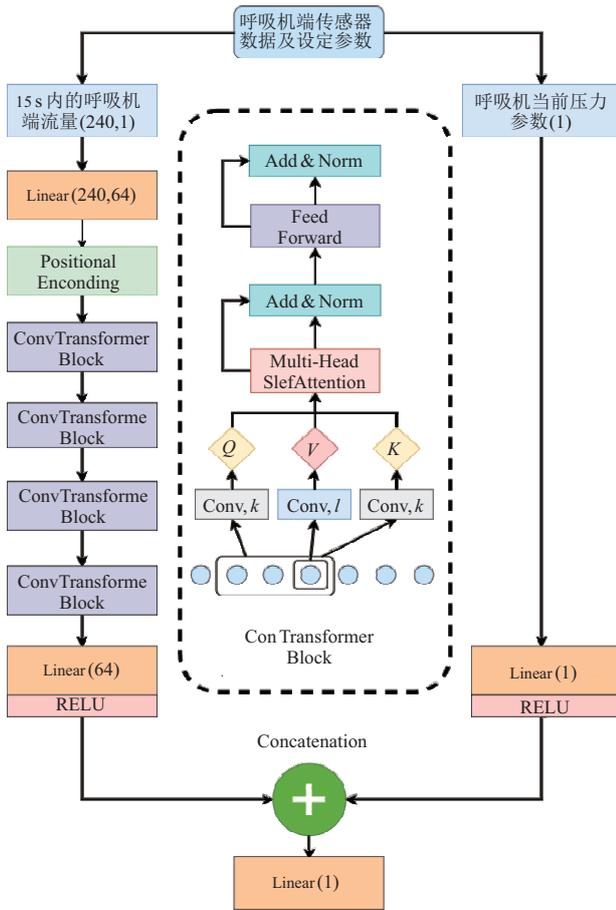


图4 漏气检测算法结构

在时序特征分支中, 首先将时序数据进行扩维, 这有利于后续结构中多头注意力机制提取不同维度上的相关特征. 同时对已扩维的时序数据增加位置编码 (positional encoding), 为时序数据中的每个点增加对应的位置信息. 将处理后的时序数据通过堆叠的 ConvTransformer Block 提取序列性的特征. 在时间序列中上下文信息非常重要, 为了在计算查询向量 (queries) 与键向量 (keys) 之间相似性时引入局部区域感受信息, ConvTransformer 模型^[28] 基于原始 Transformer, 在计算相关性矩阵值时引入卷积结构, 使用核大小为 k 、步幅为 1 的因果卷积将输入转换为 queries 和 keys. 这里使用因果卷积是考虑到输入变量为传感器时序数据, 在到达相应时间点前获取不到未来时间点的信息. 通过因果卷积的掩膜 (mask) 方式, 去除未来时间点对当前时间点的链接, 只保留当前时间点与过去时间点的链接, 以满足现实场景中各时间点的前后关联. 最后, 将协变量分支中的呼吸机设置压力作为协变量特征值与时序分支提取出的时序特征值相拼接, 经过全连接层得到当前人为、非人为漏气的回归值.

2.2.2 面向常态性与突发性病症的实时滴定算法

前文呼吸机的初始设置参数仅能确保对对应病症患者的呼吸运动起到一定的支持作用. 若想根据病情发展对患者进行个性化治疗, 需要实时检测患者状况并调节呼吸机参数, 因此本文设计了实时滴定算法. 根据患者病症不同, 所设计实时滴定算法中的状态参数及累积时间有所不同. 算法分为常态性病症与突发性病症两种滴定方式, 两种算法均在初始参数设置的基础上.

对于常态性病症如 COPD、ARDS, 呼吸机实时滴定算法关注于血氧饱和度和潮气量 (tidal volume, TV), 通过检测患者这两项指标可以评估患者氧合状态和呼吸功能, 并以此为标准逐步调整呼吸机的参数以达到患者最佳氧合指标. 其中血氧饱和度数据通过血氧探头对患者的实时采集, 经串口传输到主机端. 潮气量数据由患者端吸气流量数据 (呼吸机端采集到的流量数据去除漏气量) 积分得到, 有

$$TV = \int_0^{T_i} Q_{\text{hum}} dt = \int_0^{T_i} (Q_{\text{Tot}} - Q_{\text{leaka}} - Q_{\text{leakb}}) dt. \quad (1)$$

其中: Q_{hum} 表示患者端呼吸流量; Q_{Tot} 表示呼吸机端检测到的流量, 即管道中的总流量; Q_{leaka} 、 Q_{leakb} 分别表示人为漏气和非人为漏气.

对于突发性病症, 如 OSAHS, 除关注患者血氧饱和度和度外, 呼吸机实时滴定算法会根据 5 min 内低通气事件发生次数对呼吸机参数进行调节. 低通气事件数通过将本次呼吸潮气量值与正常潮气量值阈值 K_{VT} 的 50% 进行对比得到, 若本次呼吸潮气量值小于该阈值 K_{VT} 的 50%, 则认为出现低通气呼吸, 将每次连续的低通气呼吸时间进行累积, 若累积低通气时间持续 10 s 以上, 则记为发生一次低通气事件 (正常潮气量值阈值 K_{VT} 是通过计算 5 min 内患者前 25% 潮气量的平均值得到, 该比例在数据库的数据测试中对低通气事件的判断正确率最高.).

在实时滴定算法中, 首先获取该状态下对应累积时间 (常态性病症为 1 min、突发性病症为 5 min, 累积时间的选取是根据对应病症的呼吸机建议调节频率制定) 内的状态参数, 并判断两个状态参数值的大小. 若检测指标均达到临床医学正常氧合指标, 则视为患者已达到通气治疗效果, 此时呼吸机端设置参数值即为当前患者最适宜参数值, 停止对呼吸机参数的改变, 并继续检测患者状态以防患者状态出现变化. 若尚未达到正常氧合指标, 则在进行参数滴定操作之前先对目前的呼吸机参数进行异常判断, 若此时呼吸机参数已经超过对应呼吸机模式下的安全上

限,则再增加压力会对患者产生不良影响,此时可以认为该患者的状态不适宜当前治疗模式,应通过报警操作提醒使用者查看患者状况,并进行后续干涉.若未超过对应模式下呼吸机的安全上限,则尚在调节范围内.实时滴定算法对呼吸机参数进行相应调节,为保证患者呼吸舒适,呼吸机参数调节不宜过于频繁.这里采用UPTODATA临床医学数据库中建议的呼吸机滴定频率对呼吸机参数进行改变.实时滴定算法持续整个呼吸机治疗过程,若患者在治疗过程中产生病情异化,则对呼吸机参数进行及时调节.常态性病症与突发性病症在滴定过程中所用临床医学正常氧合指标、呼吸机安全上限及呼吸机滴定频率如表2所示.

表2 各病症实时滴定算法参数

病症	累积时间 (min)	通气模式	氧合指标	上限 (cmH ₂ O)	滴定频率 (cmH ₂ O)
COPD	1	BiPAP	TV > 5 ml/kg SpO ₂ > 92%	IPAP < 20 EPAP < 10	IPAP + 2 EPAP + 1
ARDS	1	BiPAP	TV > 6 ml/kg SpO ₂ > 92%	IPAP < 20 EPAP < 10	IPAP + 2 EPAP + 1
OSAHS	5	CPAP	AHI = 0 SpO ₂ > 92	CPAP < 15	CPAP + 1

3 仿真实验与阈值设置

本文搭建了自适应呼吸机实验平台模拟呼吸机真实使用场景,以验证无创呼吸机自适应算法中各部

分算法的有效性.实验平台由ASL5000^[29]主动模拟肺作为人体端模拟呼吸与新松DPAP30 Pro(V2)作为呼吸机通气平台组成.

3.1 参数初始化算法的仿真验证

选取ARDS(急性呼吸窘迫综合征)、COPD(慢性阻塞性肺疾病)、OSAHS(睡眠呼吸暂停综合征)3种常应用无创呼吸机治疗的呼吸病症与Normal(正常呼吸)作为验证参数初始化算法的呼吸状态,使用呼吸机内置的压力、流量、潮气量传感器实时记录不同呼吸状态产生的时序数据,完成对呼吸数据的仿真.

3.1.1 单呼吸检测算法有效性验证

使用预处理的仿真数据测试集(共12000个样本)对所提出的单呼吸检测算法与基于阈值的检测算法、传统机器学习的SVM、KNN分类算法及CNN-LSTM时间序列分类算法^[30]进行性能对比,各算法性能如表3所示.单呼吸检测算法、SVM、KNN分类算法及CNN-LSTM算法在测试集上的混淆矩阵如图5所示.

表3 各呼吸检测算法的分类表现

算法	Pre	Recall	F ₁	Acc
基于阈值	0.744	0.737	0.740	0.739
基于KNN	0.857	0.859	0.857	0.858
基于SVM	0.882	0.883	0.881	0.882
基于CNN-LSTM	0.918	0.919	0.918	0.919
单呼吸检测算法	0.988	0.989	0.987	0.989

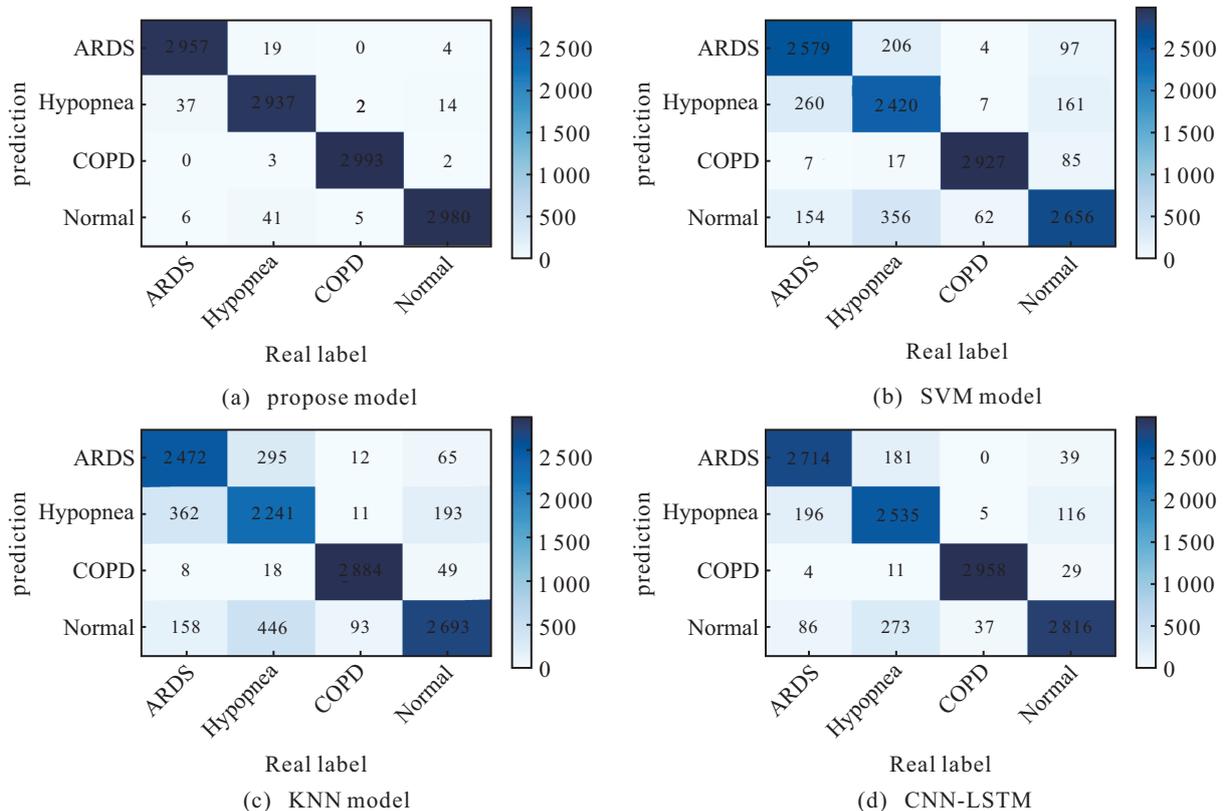


图5 不同算法的分类混淆矩阵

如表3所示,基于阈值的算法相较其他算法的分类表现较差,这是因为该方法受阈值选择的影响很大.本文数据集来自不同的患者以及不同的病情严重程度,因此设定的单一阈值在面对不同呼吸波形时会表现出较大差异.传统机器学习模型KNN、SVM的总识别准确率相较基于阈值的算法分类精度在各个类别都有较大提升,分别达到85.8%、87.4%.

CNN-LSTM算法则得到进一步提升,分类准确度达到91.6%.所提出的网络在识别准确率、敏感性、特异性和 F_1 分数上皆有所提高,分类精度达到98.9%,如表3所示.可以看出,本文单呼吸检测算法能够准确分类出单次呼吸的类别.

为了表明本文算法的可解释性和稳定性,对Recurrent Block后的循环注意力机制进行分析.该注意力权值揭示了输入特征中不同时间步对最终识别结果的影响,图6展示了4种呼吸类别在不同时间步下注意力权重的大小,横坐标表示输入特征的时间步数,纵坐标表示注意力机制为该时间步下特征分配的权重大小.可以看出,模型对不同呼吸类型特征的权重分配有明显差异,这从侧面验证了所提出方法能够有效提取区分不同呼吸类型所需的潜在信息.通过观察不同时间步下权重大小发现,对于COPD,注意力机制主要关注第5~第20时间步,这是由于COPD状态在前中期吸气过程都较为平缓,与其他3种呼吸波形差异较大;ARDS呼吸状态则关注时间步30以后的信息,这是由于ARDS在后期与其他呼吸状态差别逐渐增大;对于Normal状态和Hypopnea状态,注意力机制权重均随时间步的增大不断减小,其中Hypopnea权重下降速度较Normal状态较慢,该现象在一定程度上体现了Hypopnea和Normal状态更关注吸气初始阶段,同时体现了二者在呼吸波形上相似,分类较为困难.综上,通过图6验证了本文算法输出的合理性.

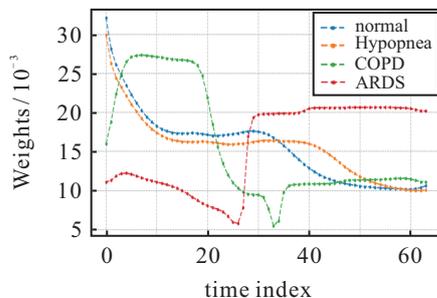


图6 4类呼吸的注意力权重

3.1.2 累积判断算法中判断阈值确定

如前文所述,对于常态性病症,累积判断算法将对应呼吸类别出现比例与设定阈值进行比较,以实

现对应呼吸类别的判断,进而设定呼吸机的初始参数.为了保证对应呼吸状态阈值设定的合理性,本文进行如下仿真实验.

将1小时的ARDS与COPD的呼吸数据集分别输入单呼吸检测算法中,统计该单呼吸检测算法输出呼吸类别的判断准确度.其中:在ARDS数据集上1小时内数据判断总准确率为99.1%,COPD数据集上判断总准确率为99.3%.考虑该实验为仿真实验,真实呼吸数据可能包含噪声等干扰现象,导致判断准确率低于仿真实验.因此在设定阈值比例时,放宽对ARDS、COPD的判断标准,将ARDS与COPD的阈值比例设置为95%,即若1小时内的单呼吸判断结果集中ARDS或COPD的比例超过95%,则认为当前患者出现该种病症并进行该病症的初始参数设置,具体实验结果如表4所示.

表4 累积判断算法常态化病症阈值实验

病症	数据量	1小时内准确率/%	设置阈值比例/%
ARDS	1836	99.1	95
COPD	1267	99.3	95

3.2 逐步滴定算法的仿真验证

漏气仿真实验平台对呼吸机不同输出压力、漏气程度进行模拟仿真.呼吸机输出压力分别取5、8、12、16、18、20 cmH₂O,不同非人为漏气程度采用不同开启程度的节流阀阀门进行模拟,得到对应呼吸机端、人为漏气端和非人为漏气端传感器的流量数据与呼吸机输出压力数据.

将本文漏气检测算法与现有呼吸机漏气检测算法、RNN、LSTM、原始Transformer encoder Block等时序回归深度学习模型在大小为6900的测试集上进行比较,计算不同呼吸机漏气检测算法在人为和非人为漏气数据上的MAE和MSE值.由于现有呼气末流量检测法和潮气量检测法无法区分人为漏气和非人为漏气,测试这两种方法时,计算该算法检测出的漏气总和与实际人为、非人为漏气总和之间的均方误差(mean squared error, MSE)、平均绝对误差(mean absolute error, MAE),各算法具体结果如表5所示.

表5 各漏气检测算法结果对比

Model	非人为		人为		Total	
	MSE	MAE	MSE	MAE	MSE	MAE
呼气末流量检测法	—	—	—	—	2.379	1.08
RNN	0.182	0.046	0.138	0.038	—	—
LSTM	0.064	0.024	0.052	0.019	—	—
Transformer encoder	0.044	0.019	0.040	0.018	—	—
ConvTransformer	0.039	0.020	0.032	0.017	—	—

实验结果表明,现有呼气末流量检测法、潮气量检测法在设计时并未考虑每一次呼吸中产生的流量变化,因此误差较大,其中呼气末流量检测法的MSE值为2.379、MAE值为1.08。与现有漏气检测算法相比,深度学习模型的MAE和MSE值均有显著降低。其中基于循环结构的LSTM在人为漏气上的MSE、MAE分别为0.052、0.019;在对非人为漏气数据进行回归时,由于非人为漏气波动较大,效果稍逊,MSE、MAE分别为0.064、0.024。得益于Transformer结构捕获长距离依赖和交互的能力,Transformer encoder模型在测试集上表现良好,优于循环类神经网络。在人为和非人为漏气测试集上,Transformer encoder模型的MSE均低于0.05。而本文使用的ConvTransformer结构相对于Transformer encoder回归误差得到了进一步下降,在人为和非人为漏气数据上取得了0.032和0.039的MSE结果。因此,本文设计的漏气检测算法无论是与现有呼吸机漏气检测算法还是与过往时序回归的深度学习模型相比,都取得了更小的回归误差。

3.3 自适应算法中深度学习计算资源与时耗分析

通过前文分析,在引入深度学习算法后本文算法在分类准确率与回归误差等多项指标上均优于传统呼吸检测与漏气检测算法。但深度学习算法的参数数量较大,对应的运算时耗较长,因此需要进行实验以检验是否满足对应任务的时间约束。采用的测试工作站为AMD Ryzen 75 800 H CPU, 32 GB内存, NVIDIA GeForce RTX 3070 GPU。经过实验,对应计算资源与时耗分析如表6所示。单呼吸检测算法所需的模型参数数量和FLOPs分别为119 425 920和183 486,处理1小时数据的时耗为33 s。由于该算法使用呼吸机历史数据离线分析,认为33 s的时耗满足时间约束。漏气检测算法所需的模型参数数量和FLOPs分别为7393 280和17 735,其运行一次呼吸数据的时间为62 ms,远远小于一次正常呼吸所需的3~5 s,因此认为62 ms的时耗满足时间约束。

表6 深度学习部分时耗分析

算法	params	flops	times
单呼吸检测算法	183 486	119 425 920	33 s
漏气检测算法	17 735	7 393 280	62 ms

4 结论

本文针对当前呼吸机智能化程度较低、自适应性研究较欠缺的问题,提出了一套基于感知融合的无创呼吸机自适应算法。在分析过往无创呼吸机操作规范及治疗病例的基础上将整个算法分为参数初

始化算法和逐步滴定算法两个部分,其中参数初始化算法根据患者历史数据选择适宜的呼吸机通气模式及初始参数,避免过高的初始压力对患者产生二次损伤;逐步滴定算法使用流量、压强、血氧传感器实时检测患者状态参数变化,并根据当前状态参数的不同对呼吸机内参数进行调节或警报行为直至整个治疗环节结束。通过在搭建的仿真实验平台上与过往同类型算法性能指标进行对比,验证了所提出呼吸机自适应算法的有效性。

参考文献(References)

- [1] Ippolito M, Misseri G, Catalisano G, et al. Ventilator-associated pneumonia in patients with COVID-19: A systematic review and meta-analysis[J]. *Antibiotics*: Basel, 2021, 10(5): 545.
- [2] Jiang W, Song Y. Internet of things-based home noninvasive ventilation in COPD patients with hypercapnic chronic respiratory failure: Study protocol for a randomized controlled trial[J]. *Trials*, 2022, 23(1): 393.
- [3] Orr J E, Schmickl C N, Edwards B A, et al. Pathogenesis of obstructive sleep apnea in individuals with the COPD+OSA overlap syndrome versus OSA alone[J]. *Physiological Reports*, 2020, 8(3): e14371.
- [4] Daniel P, Mecklenburg M, Massiah C, et al. Non-invasive positive pressure ventilation versus endotracheal intubation in treatment of COVID-19 patients requiring ventilatory support[J]. *American Journal of Emergency Medicine*, 2021, 43: 103-108.
- [5] MacIntyre N, Rackley C, Khusid F. Fifty years of mechanical ventilation-1970s to 2020[J]. *Critical Care Medicine*, 2021, 49(4): 558-574.
- [6] Kacmarek R M. The mechanical ventilator: Past, present, and future[J]. *Respiratory Care*, 2011, 56(8): 1170-1180.
- [7] Labarca G, Schmidt A, Dreyse J, et al. Efficacy of continuous positive airway pressure(CPAP) in patients with obstructive sleep apnea(OSA) and resistant hypertension(RH): Systematic review and meta-analysis[J]. *Sleep Medicine Reviews*, 2021, 58: 101446.
- [8] Randerath W, Verbraecken J, de Raaff C A L, et al. European respiratory society guideline on non-CPAP therapies for obstructive sleep apnoea[J]. *European Respiratory Review*, 2021, 30(162): 210200.
- [9] Li Y Y, Huang X G, Su J, et al. Mindfulness may be a novel factor associated with CPAP adherence in OSAHS patients[J]. *Sleep and Breathing*, 2020, 24(1): 183-190.
- [10] Rahul S, Avetisyan G F, Aakash P. Improvement in hypertension symptoms and measurement readings of blood pressure with non-invasive positive pressure ventilation in hypertensive patients having obstructive

- sleep apnea/hypopnea syndrome (OSAHS)[J]. *International Journal of Clinical Cardiology*, 2022, 9(4): 264.
- [11] Schwarz S B, Mathes T, Majorski D S, et al. Living conditions and autonomy levels in COPD patients receiving non-invasive ventilation: Impact on health related quality of life[J]. *BMC Pulmonary Medicine*, 2021, 21(1): 255.
- [12] Ohshimo S. Oxygen administration for patients with ARDS[J]. *Journal Intensive Care*, 2021, 9(1): 1-14.
- [13] Ahmadi A, Foroghi Ghomi S Y, Lotfi S. Controlled modes can be as effective as CPAP and BiPAP in non-invasive ventilation in COVID-19[J]. *Anesth Pain Med*, 2021, 11(5): e120405.
- [14] 谭志坚, 杨东, 郑则广. 呼吸机触发技术的现状和新进展[J]. *中国医疗设备*, 2009, 24(4): 56-59. (Tan Z J, Yang D, Zheng Z G. Current status and new development of the triggering technology in ventilators[J]. *China Medical Devices*, 2009, 24(4): 56-59.)
- [15] Rachim V P, Li G, Chung W Y. Sleep apnea classification using ECG-signal wavelet-PCA features[J]. *Bio-medical Materials and Engineering*, 2014, 24(6): 2875-2882.
- [16] Hassan A R. Computer-aided obstructive sleep apnea detection using normal inverse Gaussian parameters and adaptive boosting[J]. *Biomedical Signal Processing and Control*, 2016, 29: 22-30.
- [17] Martinez-Vargas J D, Sepulveda-Cano L M, Castellanos-Dominguez G. On determining available stochastic features by spectral splitting in obstructive sleep apnea detection[C]. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Boston, 2011: 6079-6082.
- [18] Avcı C, Akbaş A. Sleep apnea classification based on respiration signals by using ensemble methods[J]. *Bio-medical Materials and Engineering*, 2015, 26(S1): S1703-S1710.
- [19] Jiménez-García J, Gutiérrez-Tobal G C, García M, et al. Assessment of airflow and oximetry signals to detect pediatric sleep apnea-hypopnea syndrome using AdaBoost[J]. *Entropy*: Basel, 2020, 22(6): e670.
- [20] Lakhan P, Dithapron A, Banluesombatkul N, et al. Deep neural networks with weighted averaged overnight airflow features for sleep apnea-hypopnea severity classification[C]. *TENCON 2018-2018 IEEE Region 10 Conference*. Jeju, 2018: 0441-0445.
- [21] Haidar R, Koprinska I, Jeffries B. Sleep apnea event detection from nasal airflow using convolutional neural networks[C]. *Neural Information Processing*. Cham: Springer International Publishing, 2017: 819-827.
- [22] ElMoaqet H, Eid M, Glos M, et al. Deep recurrent neural networks for automatic detection of sleep apnea from single channel respiration signals[J]. *Sensors*: Basel, 2020, 20(18): e5037.
- [23] Borel J C, Palot A, Patout M. Technological advances in home non-invasive ventilation monitoring: Reliability of data and effect on patient outcomes[J]. *Respirology*, 2019, 24(12): 1143-1151.
- [24] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, 2016: 770-778.
- [25] Ma K, Zhan C A, Yang F. Multi-classification of arrhythmias using ResNet with CBAM on CWGAN-GP augmented ECG Gramian angular summation field[J]. *Biomedical Signal Processing and Control*, 2022, 77: 103684.
- [26] 杜先君, 巩彬, 余萍, 等. 基于CBAM-CNN的模拟电路故障诊断[J]. *控制与决策*, 2022, 37(10): 2609-2618. (Du X J, Gong B, Yu P, et al. CBAM-CNN based analog circuit fault diagnosis[J]. *Control and Decision*, 2022, 37(10): 2609-2618.)
- [27] Yang L, Zhang R Y, Li L, et al. Simam: A simple, parameter-free attention module for convolutional neural networks[C]. *International Conference on Machine Learning*. Piscataway: IEEE, 2021: 11863-11874.
- [28] Liu Z, Luo S, Li W, et al. Convtransformer: A convolutional transformer network for video frame synthesis[J/OL]. 2020, arXiv: 2011.10185.
- [29] Dexter A, McNinch N, Kaznoch D, et al. Validating lung models using the ASL 5000 breathing simulator[J]. *Simulation in Healthcare*, 2018, 13(2): 117-123.
- [30] Zarei A, Beheshti H, Asl B M. Detection of sleep apnea using deep neural networks and single-lead ECG signals[J]. *Biomedical Signal Processing and Control*, 2022, 71: 103125.

作者简介

邓子亨(1998—), 男, 博士生, 从事深度学习、算法硬件化等研究, E-mail: dengzh@stumail.neu.edu.cn;

李敏希(2004—), 男, 本科生, 从事深度学习的研究, E-mail: liminxi@stumail.neu.edu.cn;

沈大伟(1992—), 男, 博士生, 从事实时调度的研究, E-mail: shendw@stumail.neu.edu.cn;

邹建伟(1977—), 男, 高级工程师, 从事深度学习的研究, E-mail: 564183816@qq.com;

邓庆绪(1970—), 男, 教授, 博士, 从事实时嵌入式系统、物联网、可重构计算等研究, E-mail: dengqx@mail.neu.edu.cn.